

Uso de la correlación estadística para la gestión energética en locales de oficina empleando técnicas de la Industria 4.0

Use of statistical correlation for energy management in office premises adopting techniques of the Industry 4.0

Mónica Hernández-Luna¹, Roberto Robledo-Fava¹, Pedro Fernández-de-Córdoba¹, Ángel Paredes², Humberto Michinel² y Sonia Zaragoza³

¹ Universidad Politécnica de Valencia (España)

² Universidad de Vigo (España).

³ Universidad de A Coruña (España).

DOI: <http://dx.doi.org/10.6036/8844>

La actividad humana es la principal responsable del consumo de energía en edificios, que, a su vez, representa una fracción importante del gasto energético mundial y es un factor importante para el impacto ambiental [1, 2]. Por otro lado, la actividad humana se puede controlar a través de los niveles de concentración de dióxido de carbono (CO₂) del ambiente interior [3, 4, 5]. El seguimiento de la ocupación y la evaluación de su efecto sobre las principales variables ambientales de interior es un paso esencial para hacer predicciones precisas de la demanda de energía de los edificios [6]. Además, controlar la cantidad de CO₂ es importante ya que, incluso en concentraciones moderadas, puede producir incomodidad, afectar la salud de los ocupantes o reducir la eficiencia de los trabajadores, entre otros efectos [7]. Dado que las variables energéticas y ambientales son cruciales y están interrelacionadas, es

interesante estudiarlas en combinación, con el objetivo final de proporcionar los datos que pueden respaldar una toma de decisiones inteligente [8, 9].

Los estándares internacionales más importantes como los de la Sociedad Americana de Ingenieros de Calefacción, Refrigeración y Aire Acondicionado (ASHRAE) o la Organización Internacional de Normalización (ISO), y organizaciones como la Organización Mundial de la Salud, la Agencia de Protección Ambiental en EE. UU. o la Comisión Europea imponen el uso de sensores de CO₂ como indicador de la calidad del aire [10]. Por lo tanto, el acceso a los datos de concentración de CO₂ será masivo y muy asequible en el futuro cercano.

En este contexto, se han desarrollado muchos enfoques matemáticos y computacionales diferentes para comprender los datos ambientales de interiores y hacer uso de ellos para mejorar el rendimiento de los edificios. Incluyen, solo mencionando algunos ejemplos, modelos simplificados en términos de ecuaciones diferenciales [11], análisis de *big data* [12], algoritmos de optimización [13] y métodos estadísticos [14]. El proceso de detección, modelado y actuación es fundamental para la eficiencia energética y constituye un tema de gran interés para una creciente comunidad de

matemáticos, científicos e ingenieros. Debe allanar el camino para los sistemas de seguimiento del consumo con la precisión suficiente para hacer comparaciones entre las diferentes estrategias de ahorro tanto a nivel de decisión pública como privada [15, 16].

En el presente trabajo, proponemos estudiar la relación entre dos variables clave del rendimiento del edificio: el consumo de energía y la concentración de CO₂, cuyas correlaciones no han sido consideradas en la literatura. Lo hacemos analizando y comparando dos lugares de trabajo ubicados en diferentes continentes. La adquisición de datos se realizó en condiciones reales con un sistema simple y económico para medir, transmitir y gestionar la información. Los estudios de caso sobre los aspectos ambientales y energéticos pueden proporcionar información importante en el estudio de la sostenibilidad del edificio; véase, por ejemplo [17]. La mejora de la gestión de la energía en la industria de servicios implica un conocimiento profundo de la actividad humana, que se refleja en el CO₂ y el consumo de las instalaciones utilizadas por los ocupantes. Por lo tanto, la determinación matemática de la relación entre los dos facilitará en gran medida la programación de algoritmos en las plataformas de gestión de energía que están comenzando a implementarse en la industria del sector de servicios para su automatización y control.

Dado que tanto el consumo de energía como la concentración de CO₂ están relacionados con la ocupación y actividad humanas, nuestra hipótesis principal es que deben existir correlaciones positivas significativas entre ellas. Sin embargo, el

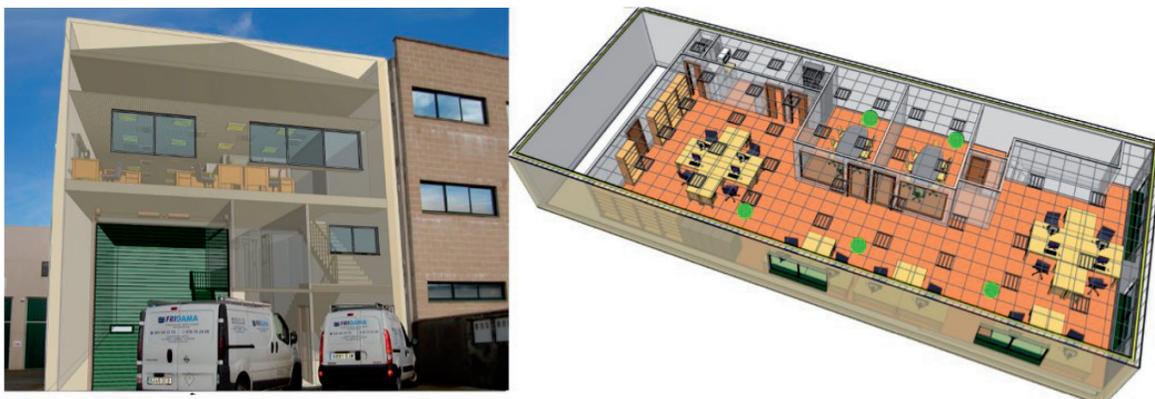


Fig (1): El edificio en España. Izquierda: vista de la parte externa del edificio con una simulación 3D superpuesta. Derecha: detalle de la posición de los sensores de CO₂ dentro de la oficina (puntos verdes)

problema no es tan obvio. Por ejemplo, una ventilación fuerte puede resultar en niveles reducidos de CO₂ mientras que aumenta el gasto de energía y la tasa de ventilación tiene un fuerte impacto estacional en muchos edificios. Por otro lado, las personas emiten diferentes cantidades de CO₂, dependiendo de sus tasas metabólicas, que pueden verse afectadas por la estación y la ropa. Además, puede haber cargas eléctricas que no dependen de la presencia de personas, lo que limita de nuevo la cantidad de correlación. Por lo tanto, se puede esperar que la asociación entre el uso de energía de un ocupante y la tasa de emisión de CO₂ tenga una notable dispersión, lo que resultaría en una reducción de los coeficientes de correlación.

La comparación de dos cantidades fácilmente mensurables, como el consumo de energía y la concentración de CO₂, puede ser útil para comprender el rendimiento de una instalación y la actividad humana en su interior. Para extraer conclusiones, es necesario hacer un análisis comparativo de diferentes conjuntos de datos y este trabajo pretende dar un paso en esta dirección. Postulamos que contrastar los resultados de diferentes industrias o partes de ellas, o para la operación del mismo edificio bajo diferentes condiciones climáticas puede proporcionar información valiosa, pruebas de eficiencia y, a medio plazo, indicadores útiles para la toma de decisiones. Las plataformas de energía digital en la nube serán fundamentales para este propósito, en el contexto del rápido desarrollo de la industria 4.0.

2. MATERIAL Y MÉTODOS

2.1. DESCRIPCIÓN DE LAS INSTALACIONES

Los sensores se colocaron en colaboración con una empresa privada española (Fridama Instalaciones, S.L.) que

diseña, calcula e instala aire acondicionado y sistemas eléctricos. La compañía tiene oficinas en varias áreas del mundo con diferentes condiciones climáticas, como España y Panamá, pero con programas de actividad y ocupación similares. Hacer el estudio en dos partes diferentes del mundo con legislaciones y climatología dispares pero con ocupación y actividad comparables es útil para contrastar la metodología y los resultados. El edificio de Instalaciones Fridama en Sada (España) consta de dos plantas. El almacén, en la planta baja, tiene una superficie de 250 m². La planta superior comprende las oficinas técnicas y administrativas, donde trabajan 12 personas y ocupan un área de 200 m². En la Fig. (1) se presenta un esquema de la distribución de la sede de la compañía.

El sistema de monitorización, supervisión y control incluye cinco sensores de CO₂ ubicados siguiendo las pautas de ASHRAE 62.1 [10] en términos de zonas de respiración y la ubicación de las estaciones de trabajo, ver Fig. (1). También hay divisiones de líneas eléctricas, diseñadas para que el consumo de las instalaciones sea independiente y para permitir su monitorización por separado. Las cargas eléctricas principales son el equipo de aire acondicionado, que comprende un analizador y un dispositivo de control para que su funcionamiento se controle por temperatura de punto de ajuste y por programa de ocupación; un sistema de iluminación con una potencia instalada total de 5kW; y el sistema de automatización de oficinas con catorce computadoras, un servidor y tres impresoras (4kW de potencia instalada).

Las oficinas centrales de Fridama Panama en Clayton (Ciudad de Panamá, República de Panamá) consisten en una sola planta de 111.2 m² que comprende el almacén, las oficinas técnicas y administrativas. Al igual que en España, los sensores de CO₂ se ubicaron en diferentes zonas de la planta. También se instalaron

analizadores de red para monitorizar el consumo general de las instalaciones y los controladores regulan el funcionamiento de las instalaciones de acuerdo con la ocupación humana.

2.2. MÉTODOS PARA LA ADQUISICIÓN DE DATOS

El proceso automatizado de recopilación de datos se llevó a cabo utilizando los microcontroladores ESP8266, proporcionando visualización en tiempo real de los valores ambientales. El microcontrolador se utilizó con una tensión de funcionamiento en el rango de 3 a 3.6V [18], siendo necesario colocar un regulador de voltaje (D24V3F3). El dispositivo utilizado para controlar el clima de la sala entera es el AERASGARD® RFTM-LQ-CO₂ controlado por microprocesador. Mide la concentración de CO₂ (por medio de tecnología infrarroja óptica no dispersiva [19]) en el rango de 0 a 5000 partes por millón, junto con la temperatura y la humedad relativa del aire. En la Fig. (2), se presentan dos fotografías del sistema instalado.

El proceso de comunicación entre el microcontrolador y los sensores utiliza el protocolo I2C programado en LUA. Este lenguaje se usa porque es compacto, puede incorporarse a otras aplicaciones con facilidad y tiene administración de memoria automática [20]. Los datos se envían a través de Internet con el protocolo *Message Queue Telemetry Transport* [MQTT] que es liviano y consume poco ancho de banda [21]. La arquitectura de MQTT sigue una topología en estrella, con un nodo central que actúa como servidor o "intermediario", que en este caso es el software MOSQUITTO. La plataforma web EQUUS [22] fue utilizada para supervisión, monitorización y control. Permite el acceso a la información tanto en tiempo real como con datos históricos.

2.3. MÉTODOS ESTADÍSTICOS

La siguiente sección presenta un análisis de los datos adquiridos que se basa en métodos estadísticos estándar; ver por ejemplo [23]. En particular, utilizamos la regresión lineal estándar, que incluye el cálculo de los coeficientes de correlación de Pearson y el diagnóstico del modelo basado en el análisis de residuos. También recurrimos a métodos de regresión no lineal, en particular calculando el coeficiente de correlación de Spearman (una medida no paramétrica de la correlación de rangos entre dos variables que estima su posible relación usando una función monótona) y un estimador

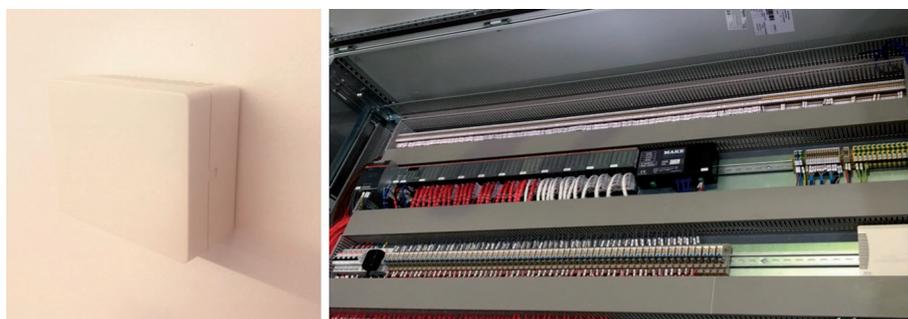


Fig (2): Dos fotografías de la instalación en la oficina española. Izquierda: uno de los sensores colgando en la pared. Derecha: el panel de control

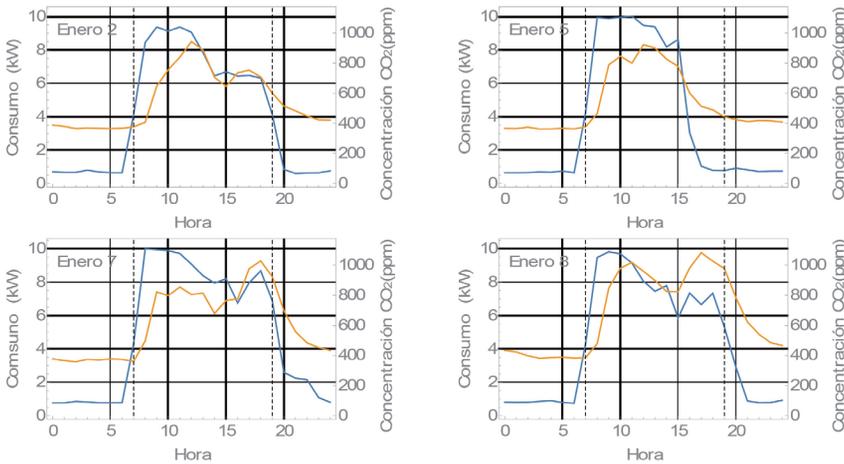


Fig (3): Evolución comparada en días hábiles típicos en Sada. Se muestra el consumo de energía (línea azul) y la concentración de CO₂ (línea naranja). Las curvas para los datos medidos en Panamá son cualitativamente similares

no paramétrico de Nadaraya-Watson para una función de regresión desconocida. Los cálculos se realizaron utilizando R, el conocido entorno de software libre para la informática estadística [24].

3. RESULTADOS

En esta sección, realizamos un análisis estadístico de un año de datos medidos en la oficina en Sada (del 1 de enero de 2015 al 31 de diciembre de 2015) y en Clayton (del 14 de octubre de 2016 al 13 de octubre de 2017). Las mediciones de la concentración de CO₂ (en partes por millón) y la potencia (P) que se consume (en kilovatios) se tomaron cada hora. (Para el caso panameño, el análisis excluye el consumo de aire acondicionado: cuando se toma en cuenta el sistema de aire acondicionado, las correlaciones son mucho más débiles, presumiblemente porque sigue un patrón automático para su encendido y apagado. Volveremos a este punto al final de esta sección.) La Fig. (3) muestra cómo la concentración de CO₂ y P se comportan en días hábiles típicos. Se elevan rápidamente al comienzo de las horas de

trabajo, oscilan de forma aparentemente aleatoria durante ese período y comienzan a disminuir después. Durante las horas sin ocupación, P se reduce a un valor aproximadamente constante por debajo de 1 kW y la concentración de CO₂ tiende al valor exterior. Es evidente que existe un cierto grado de correlación entre ambas cantidades. Durante los fines de semana y las vacaciones, ambas curvas permanecen prácticamente planas.

La Fig. (4) muestra gráficos de dispersión que representan todas las mediciones a lo largo del año. Una prueba de asociación entre muestras pareadas arroja p-valores insignificantes en ambos casos, lo que demuestra que P y la concentración de CO₂ no son estadísticamente independientes. La posibilidad más simple es postular un modelo de regresión lineal:

$$CO_2(\text{ppm}) \approx (372 \pm 2) + (59.9 \pm 0.7) P(\text{kW}) \text{ (oficina en España),}$$

$$CO_2(\text{ppm}) \approx (394 \pm 1) + (189 \pm 2) P(\text{kW}) \text{ (oficina en Panamá),}$$

donde hemos indicado los mejores parámetros de ajuste y sus errores

estándar. Los coeficientes de correlación de Pearson son $r = 0.72$ (España) y $r = 0.68$ (Panamá), lo que indica que existen correlaciones positivas significativas entre las variables. Ciertamente, también hay una cantidad significativa de variación no explicada.

Vale la pena comentar sobre las correlaciones encontradas para subconjuntos particulares de datos. Por ejemplo, en el caso español, cuando los fines de semana y las vacaciones (que en su mayoría contribuyen a la nube de puntos en la parte inferior izquierda de la figura) se excluyen, encontramos un ligero cambio en el coeficiente de Pearson ($r = 0.67$). Esto se reduce un poco más cuando las horas nocturnas sin presencia humana también se excluyen, aunque una correlación considerable permanece ($r = 0.53$). Por otro lado, si solo se tienen en cuenta las vacaciones y los fines de semana, tanto P como el CO₂ oscilan de forma aleatoria alrededor de sus valores mínimos y, como cabría esperar, su correlación es insignificante ($r = 0.04$).

El diagnóstico del modelado lineal se realiza analizando los residuos, es decir, las diferencias entre los valores observados de concentración de CO₂ y los predichos por las expresiones de mejor ajuste. Los paneles izquierdos de la Fig. (5) presentan gráficos de dispersión de los residuos. Es evidente que los datos en realidad no cumplen la hipótesis de homocedasticidad. Para valores grandes de P, la mayoría de los residuos son negativos; indicando claramente que el ajuste lineal tiende a sobreestimar la concentración de CO₂ en esa región de parámetros (el efecto es más marcado para la oficina española). El histograma de residuos muestra que siguen, en ambos casos, una distribución acampanada (no gaussiana).

Por tanto, aun siendo el ajuste lineal una primera aproximación conveniente, los datos no cumplen completamente con las hipótesis típicas de la regresión lineal. Por esta razón, es interesante considerar también modelos más generales. Los coeficientes de Spearman, que suponen que las variaciones de las variables están relacionadas monótonamente, pero no necesariamente linealmente, son $r_s = 0.68$ (Sada) y $r_s = 0.59$ (Clayton). En la Fig. (4), hemos incluido el resultado de un ajuste no paramétrico basado en un estimador de Nadaraya-Watson. En el caso español, esta estimación es significativamente menor que la lineal para $P \geq 8$ kW. Curiosamente, parece que la concentración promedio de CO₂ se aplatina y deja de crecer para esos valores de P.

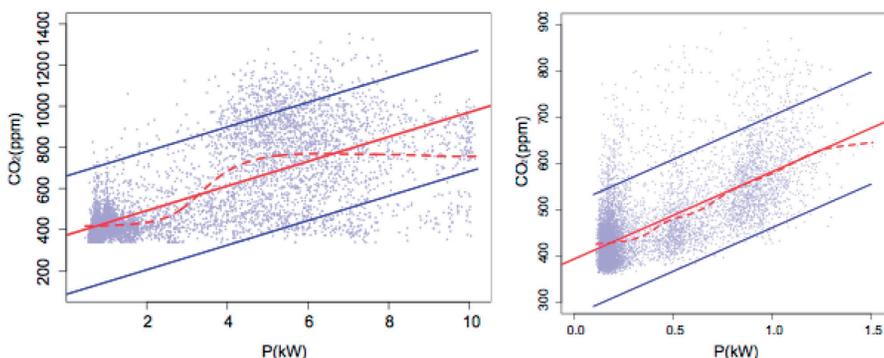


Fig (4): Diagramas de dispersión de las muestras de datos. Los puntos azules corresponden a mediciones individuales. La línea continua roja es la que mejor se ajusta al modelo de regresión lineal y las líneas continuas azules marcan sus intervalos de predicción con un nivel de confianza del 95%. La línea roja discontinua es una regresión no paramétrica que utiliza un estimador de Nadaraya-Watson

Otra cuestión interesante es si la relación entre P y concentración de CO_2 varía a lo largo del año. Hemos repetido el análisis realizando separadamente el cálculo de regresión lineal para cada uno de los meses del año. Cualitativamente, trazados similares a los de las Figs. (3-5) se encuentran en todos los casos. En la Fig. (6), representamos los coeficientes de correlación, calculados por separado para cada mes. Ambos coeficientes permanecen en todos los casos no lejos de 0.7 y no se puede apreciar una variación estacional clara.

Algunos detalles varían de mes a mes. Por ejemplo, en los meses fríos de Sada (enero, febrero, noviembre, diciembre), los ajustes lineales suelen sobreestimar la concentración de CO_2 al comienzo de la jornada laboral. Presumiblemente, la razón es que la calefacción se enciende repentinamente, aumentando la demanda de energía, pero lleva un tiempo después de la llegada de los trabajadores que los niveles de CO_2 crezcan. Esto se puede apreciar en la Fig. (3), donde por la mañana se puede ver que el aumento de P ocurre antes que el aumento en la concentración de CO_2 . De hecho, si para los meses antes mencionados se eliminan de la muestra los datos correspondientes a las 07:00 y 08:00 durante los días hábiles, el valor de r crece, llegando a alcanzar 0.83 para el mes de enero.

La Fig. (7) compara los coeficientes de los ajustes lineales de los datos para cada mes por separado. En España, la intercepción (ordenada en el origen), que está relacionado con la concentración de CO_2 al aire libre, permanece aproximadamente constante durante todo el año. El mes de noviembre es un caso atípico en este sentido, presumiblemente en relación con los problemas del sistema de adquisición de datos. Curiosamente, la pendiente es significativamente más alta para el período de agosto a noviembre, pero no hemos encontrado una explicación convincente para este hecho peculiar. En Panamá, la intercepción permanece aproximadamente constante durante un período del año, pero hay una disminución clara de enero a abril. Estos son precisamente los meses más ventosos en la Ciudad de Panamá, que implican una caída de la concentración de CO_2 al nivel del suelo. Por otro lado, vemos que la pendiente tiende a aumentar a medida que pasan los meses. Esto podría estar relacionado con la ocupación de la oficina, ya que una pendiente más grande significa que un cierto aumento en el gasto de energía da como resultado un

mayor aumento en la concentración de CO_2 .

Finalmente, es interesante comparar los resultados descritos con otro tipo de locales, donde se pueden esperar resultados diferentes para la correlación entre el consumo de energía y la concentración de dióxido de carbono. Por ejemplo, muchas áreas comerciales funcionan con sistemas automatizados y los gastos apenas dependen de la cantidad de clientes. En la Fig. (8), presentamos una comparación de una semana de datos para un área recreativa en Panamá. Si bien la curva de consumo de energía es similar todos los días, los picos de concentración de CO_2 son mucho más prominentes durante el fin de semana, especialmente los sábados.

En el caso de la Fig. (8), el coeficiente de Pearson para el mes de datos que tenemos disponible es $r = 0.26$. Se obtiene un resultado similar para una tienda en AltaPlaza Mall (Ciudad de Panamá), donde encontramos $r = 0.24$. En este último caso, también tenemos datos de ocupación

humana y, por lo tanto, podemos incluirlos en el análisis. Como era de esperar, durante las horas con presencia humana, el número de ocupantes se correlaciona significativamente con la concentración de CO_2 ($r = 0.74$), pero solo se correlaciona débilmente con el consumo de energía ($r = 0.31$).

En resumen, los datos disponibles sugieren que el consumo de energía no automatizado en lugares de trabajo está significativamente correlacionado positivamente con la concentración de CO_2 (alrededor de $r = 0.7$ en los casos analizados). Por otro lado, en locales con patrones de consumo automatizados, existe una correlación moderada (alrededor de $r = 0.25$ en los casos estudiados). La correlación es aún positiva porque el sistema automático normalmente gasta menos durante las horas valle (por ejemplo, durante la noche en la Fig. (8)). Esta es la razón por la cual el sistema climático automatizado fue excluido del análisis de la oficina panameña en las Figs. (4-7). De hecho, en ese caso, la correlación entre el

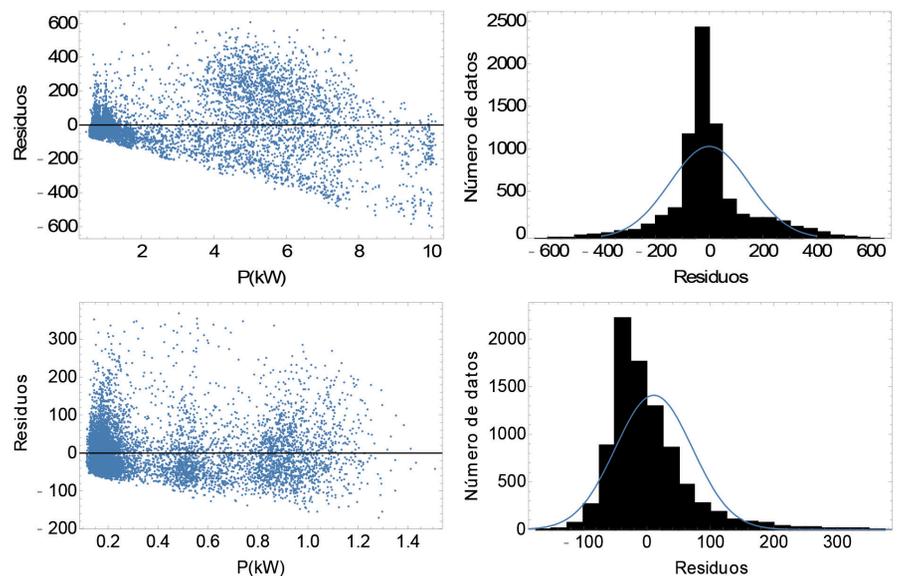


Fig (5): Diagnóstico del modelo de regresión lineal. Los paneles en la parte superior corresponden a la oficina española y los que están en la parte inferior a la oficina panameña. A la izquierda, representamos los residuos como una función de la potencia. A la derecha, se muestra un histograma de los residuos y se compara con una distribución normal con la misma normalización y desviación estándar

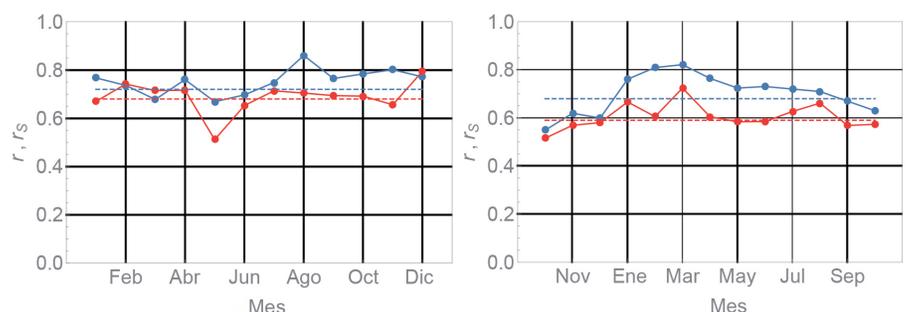


Fig (6): Los coeficientes de correlación Pearson (azul) y Spearman (rojo), calculados para las muestras de datos de los doce meses del año para las oficinas en España (izquierda) y Panamá (derecha). Las líneas punteadas horizontales marcan sus valores cuando el cálculo se realiza introduciendo todos los datos anuales

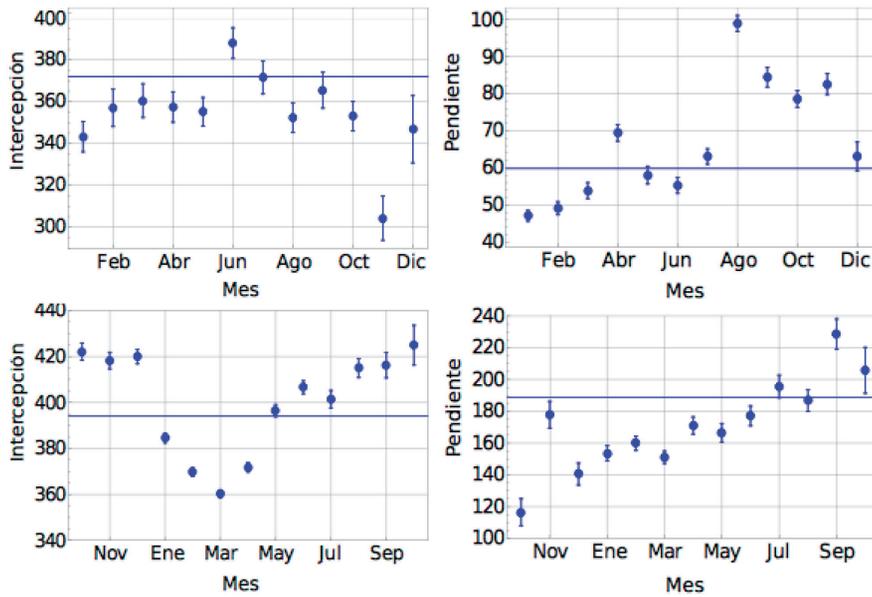


Fig (7): Coeficientes de los mejores ajustes lineales para cada mes. $CO_2 \text{ (ppm)} \approx (\text{Intercepción}) + (\text{Pendiente}) \cdot P$. Las líneas horizontales marcan las de todo el año. Las barras de error representan los errores estándar de los parámetros que mejor se ajustan. Los paneles en la parte superior corresponden a la oficina española y los que están en la parte inferior a la oficina panameña

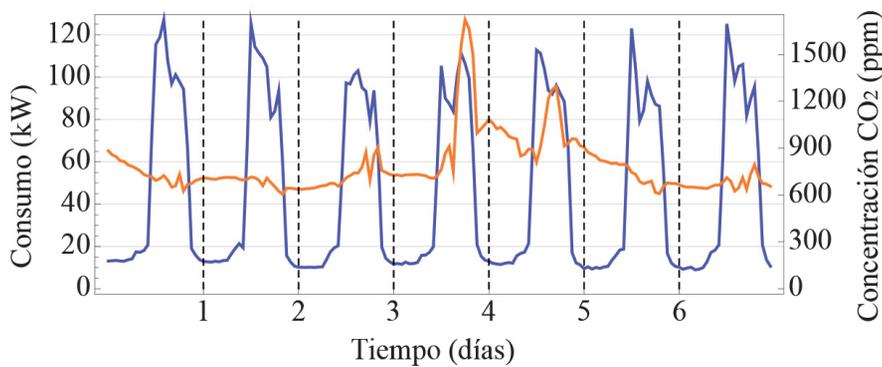


Fig. (8): Evolución comparada durante una semana, de miércoles a martes, en un área recreativa en la ciudad de Panamá. Se muestra el consumo de energía (línea azul) y la concentración de CO_2 (línea naranja). Las curvas se pueden comparar con la Fig. (3)

gasto energético del sistema climático y la concentración de CO_2 es $r = 0.34$, similar al de las áreas comerciales discutidas en el párrafo anterior.

4. CONCLUSIONES Y DISCUSIÓN

Hemos conjeturado que el gasto de energía y la concentración de CO_2 deberían presentar correlaciones positivas significativas para los lugares de trabajo. Esta relación implica que es interesante analizar el consumo de energía y las variables del ambiente interior en combinación. Ambas variables están relacionadas con la actividad humana, se pueden medir con sistemas relativamente simples y su estudio puede proporcionar un ingrediente para comprender el rendimiento de los edificios. Nuestras afirmaciones están respaldadas por unos pocos estudios de casos para los cuales tenemos datos disponibles.

No está claro en este momento si son generalizables y, por lo tanto, las conclusiones deben ser tomadas con cautela. Sin embargo, creemos que los resultados son atractivos, ya que hemos demostrado que abren nuevas vías para la interpretación de datos que estarán cada vez más disponibles en la era del internet de las cosas y de la industria 4.0.

Se instalaron sensores comerciales y se utilizó una plataforma en línea para la gestión de datos. Los dos casos discutidos aquí corresponden a dos lugares de trabajo con algunas similitudes, aunque difieren un tanto en tamaño, disposición y ocupación promedio. Además, están en diferentes continentes bajo condiciones climáticas muy diferentes. A pesar de las diferencias, hemos visto que hay algunas similitudes notables en la correlación entre el consumo de energía y la concentración de CO_2 . Un modelo de regresión lineal

simple produce coeficientes de Pearson alrededor de $r = 0.7$ en ambos casos. El coeficiente de determinación, que equivale a la proporción de la varianza en la variable dependiente que es predecible a partir de la variable independiente, viene dado por r^2 . Esto significa que alrededor del 50% de la variación del gasto de energía considerado se puede explicar con los datos de concentración de CO_2 . Este resultado se cumple independientemente de si los conjuntos de datos se agrupan mensualmente o anualmente, cf. Fig. (6). Un análisis de los residuos proporciona el mismo resultado en ambos casos: los supuestos habituales de homocedasticidad y normalidad no se satisfacen totalmente. Esto motiva el estudio paralelo y la comparación de modelos de regresión no lineales y no paramétricos. Sin embargo, la aproximación lineal sigue siendo útil ya que proporciona datos cuantitativos simples. Por ejemplo, analizar cómo esos parámetros cambian en el tiempo produce información no trivial, cf. Fig. (7), que muestra cómo la relación entre la concentración de CO_2 y P cambia debido a la variación estacional u otras causas indeterminadas. Por otro lado, hemos argumentado y comprobado que la correlación debería ser más débil para otro tipo de locales tales como las áreas comerciales donde los gastos de energía son casi independientes del número de ocupantes.

Sería interesante analizar más espacios y edificios para confirmar o refutar las tendencias generales antes mencionadas. Para entender correctamente la variación estacional, sería necesario estudiar períodos más largos en el análisis, incluyendo varios años. Agregar otros tipos de sensores también sería útil. En particular, aunque no están tan extendidos como los utilizados aquí, los sensores de presencia serían valiosos. Las técnicas de análisis estadístico multivariante pueden producir ideas y resultados importantes, a costa de complicar el modelado con la introducción de más variables ambientales. Otra mejora posible del enfoque sería combinar el procedimiento estadístico con el modelado físico simple.

Actualmente, la tendencia es hacia un sector industrial y de servicios altamente automatizado, en el marco de la llamada industria 4.0. Esto implica un alto grado de sensorización y análisis de datos. En los edificios, esto es fundamental para la toma de decisiones hacia la sostenibilidad [25]. El presente estudio tiene como objetivo proporcionar sistemas de monitorización y control mediante el estudio de correlaciones entre variables, para reducir

costes de inversión en este tipo de plataformas. Los resultados presentados para locales de oficinas durante un año, en diferentes continentes, con la misma actividad, diferentes climatologías y reglamentos técnicos han dejado en claro que este camino es posible. El estudio sugiere que el consumo global puede predecirse parcialmente a través de sensores de CO₂, a un coste aproximadamente cuatro veces menor, pero con la precisión necesaria en la automatización de la gestión y el mantenimiento de este tipo de instalaciones.

Aunque más allá del alcance de esta contribución, el objetivo de este tipo de análisis es proporcionar ideas que puedan incorporarse en modelos de optimización más complejos, como los basados en redes neuronales artificiales [26] o algoritmos genéticos [27]. También prevemos que técnicas similares podrían aplicarse en otras situaciones como, por ejemplo, la gestión de la producción de calor y la refrigeración en procesos industriales [28]. Por tanto, esperamos que este estudio contribuya al desarrollo de vías de investigación que, en el futuro, conduzcan a estrategias para comprender y mejorar el rendimiento de edificios. Estas aplicaciones potenciales se basan en plataformas energéticas inteligentes en la nube, en el contexto de la industria 4.0.

PARA SABER MÁS

- [1] Dakwale V A, Ralegaonkar R V, Mandavgane S. "Improving environmental performance of building through increased energy efficiency: A review". *Sustainable Cities and Society*, Vol. 1, nº 4 (2011), p. 211 - 218. DOI: <http://dx.doi.org/10.1016/j.scs.2011.07.007>
- [2] Lin B, Liu H. "CO₂ emissions of China's commercial and residential buildings: Evidence and reduction policy". *Building and Environment*, Vol. 92 (2015), p. 418-431. DOI: <https://doi.org/10.1016/j.buildenv.2015.05.020>
- [3] Chou C C, Chiang C T, Wu P Y et al. "Spatiotemporal analysis and visualization of power consumption data integrated with building information models for energy savings" *Resources, Conservation and Recycling*, Vol. 123 (2017), p. 219-229. DOI: <https://doi.org/10.1016/j.resconrec.2016.03.008>
- [4] Fisk W J. "Health and productivity gains from better indoor environments and their relationship with building energy efficiency". *Annual Review of Energy and the Environment*, Vol. 25, nº 1 (2000), p. 537-566. DOI: <https://doi.org/10.1146/annurev.energy.25.1.537>
- [5] Cali D, Matthes P, Huchtemann K et al. "CO₂ based occupancy detection algorithm: Experimental analysis and validation for office and residential buildings". *Building and Environment*, Vol. 86 (2015), p. 39-49. DOI: <https://doi.org/10.1016/j.buildenv.2014.12.011>
- [6] Kok N, McGraw M, Quigley J M. "The diffusion of energy efficiency in building". *The American Economic Review*, Vol. 101, nº 3 (2011), p. 77-82. DOI: <https://doi.org/10.1257/aer.101.3.77>
- [7] Satish U, Mendell M J, Shekhar K et al. "Is CO₂ an indoor pollutant? Direct effects of low-to-moderate CO₂ concentrations on human decision-making performance". *Environmental Health Perspectives*, Vol. 120, nº 12 (2012), p. 1671-1677. DOI: <http://doi.org/10.1289/ehp.1104789>
- [8] Sharmin T, Gül M, Li X et al. "Monitoring building energy consumption, thermal performance, and indoor air quality in a cold climate region". *Sustainable Cities and Society*, Vol. 13 (2014), p. 57-68. DOI: <https://doi.org/10.1016/j.scs.2014.04.009>
- [9] Pei Z, Lin B, Liu Y et al. "Comparative study on the indoor environment quality of green office buildings in China with a long-term field measurement and investigation". *Building and Environment*, Vol. 84 (2015), p. 80-88. <https://doi.org/10.1016/j.buildenv.2014.10.015>
- [10] ASHRAE, Ventilation for acceptable indoor air quality, ANSI/ASHRAE Standard 62.1.
- [11] Balvis E, Sampedro O, Zaragoza S et al. "A simple model for automatic analysis and diagnosis of environmental thermal comfort in energy efficient buildings". *Applied Energy*, Vol. 177 (2016), p. 60-70. DOI: <https://doi.org/10.1016/j.apenergy.2016.04.117>
- [12] Mathew P A, Dunn L N, Sohn M D et al. "Big-data for building energy performance: Lessons from assembling a very large national database of building energy use". *Applied Energy*, Vol. 140 (2015), p. 85-93. DOI: <https://doi.org/10.1016/j.apenergy.2014.11.042>
- [13] Ogunjuyigbe A S O, Ayodele T R, Akinola O A. "User satisfaction-induced demand side load management in residential buildings with user budget constraint". *Applied Energy*, Vol. 187, nº 1 (2017), p. 352-366. DOI: <https://doi.org/10.1016/j.apenergy.2016.11.071>
- [14] Barbeito I, Zaragoza S, Tarrío-Saavedra J et al. "Assessing thermal comfort and energy efficiency in buildings by statistical quality control for autocorrelated data". *Applied Energy*, Vol. 190 (2017), p. 1-17. DOI: <https://doi.org/10.1016/j.apenergy.2016.12.100>
- [15] dos Santos A H C, Fagá M T W, dos Santos E M. "The risks of an energy efficiency policy for buildings based solely on the consumption evaluation of final energy". *International Journal of Electrical Power & Energy Systems*, Vol. 44, nº 1 (2013), p. 70-77. DOI: <http://dx.doi.org/10.1016/j.ijepes.2012.07.017>
- [16] Hirano Y, Ihara T, Yoshida Y. "Estimating residential CO₂ emissions based on daily activities and consideration of methods to reduce emissions". *Building and Environment*, Vol. 103 (2016), p. 1-8. DOI: <https://doi.org/10.1016/j.buildenv.2016.02.021>
- [17] Rosselló-Batle B, Ribas C, Moià-Pol A et al. "Saving potential for embodied energy and CO₂ emissions from building elements: A case study". *Journal of Building Physics*, Vol. 39, nº 3 (2015), p. 261-284. DOI: <https://doi.org/10.1177/1744259114543982>
- [18] Marques G, Pitarma R. "Monitoring energy consumption system to improve energy efficiency". In: Rocha Á, Correia A, Adeli H et al. (eds.) *Recent Advances in Information Systems and Technologies*. WorldCIST 2017. *Advances in Intelligent Systems and Computing*, Vol. 570. Cham: Springer, 2017. p. 3-11. DOI: https://doi.org/10.1007/978-3-319-56538-5_1
- [19] Ekwevugbe T, Brown N, Pakka V et al. "Real-time building occupancy sensing using neural-network based sensor network". In: 2013 7th IEEE International Conference on Digital Ecosystems and Technologies (DEST), Menlo Park, CA, 2013, pp. 114-119. <http://dx.doi.org/10.1109/DEST.2013.6611339>
- [20] Plaza P, Sancristobal E, Carro G et al. "Wireless development boards to connect the world". In: Auer M, Zutin D (eds) *Online Engineering & Internet of Things*. *Lecture Notes in Networks and Systems*, Vol. 22, Cham: Springer, 2018, p. 19-27. DOI: https://doi.org/10.1007/978-3-319-64352-6_2
- [21] Light R A. "Mosquito: server and client implementation of the MQTT protocol". *Journal of Open Source Software*, Vol. 2, nº 13 (2017), p. 1-2. DOI: <http://dx.doi.org/10.21105/joss.00265>
- [22] Naya S, Tarrío-Saavedra J, Zaragoza S et al. "Statistical quality control with functional data. an application to energy efficiency" In: *Proceedings of the 60th ISI World Statistics Congress*, 26-31 July 2015, Rio de Janeiro, Brazil, 2015, pp. 3425-3432.
- [23] Cao-Abad Ricardo, Francisco-Fernández Mario, Naya-Fernández Salvador. *Estadística básica aplicada*. A Coruña: Torculo, 1998. ISBN: 9788484080244.
- [24] R Core Team. R: A language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2016. <http://www.R-project.org/>
- [25] Perea-Olabarria E, Mera-Vázquez A, Santos-Moro L et al. "Decision support system for efficient use of energy in buildings". *DYNA Energía y Sostenibilidad*, Vol. 2, nº 1 (2013) DOI: <http://dx.doi.org/10.6036/ES6901>
- [26] Chae Y T, Horesh R, Hwang Y et al. "Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings". *Energy and Buildings*, Vol. 111 (2016), p. 184-194. <http://doi.org/10.1016/j.enbuild.2015.11.045>
- [27] Congradac V, Kulic F. "HVAC system optimization with CO₂ concentration control using genetic algorithms". *Energy and Buildings* Vol. 41, nº 5 (2009), p. 571-577. <https://doi.org/10.1016/j.enbuild.2008.12.004>
- [28] Pereira O, Rodríguez A, Fernández-Abia A I et al. "Cryogenic and minimum quantity lubrication for an eco-efficiency turning of AISI 304". *Journal of cleaner production*, Vol. 139 (2016), p. 440-449. <https://doi.org/10.1016/j.jclepro.2016.08.030>

AGRADECIMIENTOS

Los autores agradecen a Fridama Instalaciones, S.L. el acceso a los datos para el presente estudio y a la plataforma energética EQUUS por el software de gestión de datos. Este trabajo fue parcialmente apoyado por las subvenciones FIS2014-58117-P, ENE2015-71333-R, MAT2017-86453-R y FIS2017-83762-P del Ministerio de Economía y Competitividad (España) así como por la subvención GPC2015 / 019 de la Consellería de Cultura, Educación e Ordenación Universitaria (Xunta de Galicia, España). R. Robledo Fava y M.C. Hernández Luna recibieron el apoyo de las becas CONACYT no. 298503 y 296471, respectivamente.